(19)日本国特許庁（ＪＰ）　(12)公開特許公報（Ａ）　(11)特許出願公開番号

特開平10－187182

(43)公開日　平成10年(1998)７月14日

(51)Int.Cl.[6]		識別記号	FI	
Ｇ１０Ｌ	3/00	５３１	Ｇ１０Ｌ　3/00	５３１Ｎ
		５１５		５１５Ｂ
		５５１		５５１Ｇ
Ｈ０４Ｎ	5/91		Ｈ０４Ｎ　5/91	Ｎ

審査請求　未請求　請求項の数12　ＯＬ　（全８頁）

(21)出願番号　特願平8－340293

(22)出願日　平成８年(1996)12月20日

(71)出願人　000004226
日本電信電話株式会社
東京都新宿区西新宿三丁目19番２号

(72)発明者　南　憲一
東京都新宿区西新宿３丁目19番２号　日本電信電話株式会社内

(72)発明者　阿久津　明人
東京都新宿区西新宿３丁目19番２号　日本電信電話株式会社内

(72)発明者　外村　佳伸
東京都新宿区西新宿３丁目19番２号　日本電信電話株式会社内

(74)代理人　弁理士　志賀　富士弥

(54)【発明の名称】　映像分類方法および装置

(57)【要約】

【課題】　映像情報に含まれる音情報を解析し、映像を既存のジャンルにとらわれないカテゴリーに分類する映像分類方法および装置を提供する。

【解決手段】　音楽検出部１０３は、入力された映像情報の音情報を周波数解析し、スペクトルの安定性を検出して音楽を検出する。音声検出部１０４は、スペクトルのハーモニック構造を検出し、音声を検出する。他方で、入力された映像情報の音情報を、符号帳生成部１０５にて学習データとして生成された符号帳の特徴ベクトルと音響検出部１０６において比較し、両者の距離の近さにより音響の種類を検出する。以上で検出された音情報の区間の位置を属性情報蓄積部１０７で記録し、検出された音情報の種類、各々の区間の長さ、種類毎の全体の長さ、各々の区間の位置のパターンを抽出して、映像情報の種類を映像判別部１０８にて判別する。

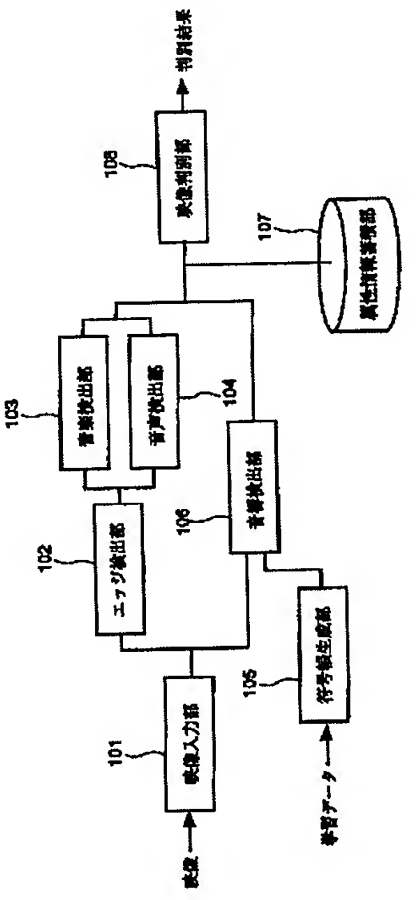

【特許請求の範囲】
【請求項１】　映像情報を入力し、該入力された映像情報に含まれる音情報から音楽、音声、音響のうち少なくとも１つが存在する区間を検出し、該検出された区間の発生パターンによって映像の種類を判別する映像分類方法であって、
映像情報がアナログの場合にはＡ／Ｄ変換してディジタルの映像情報を入力する映像入力段階と、
該映像情報に含まれる音情報を周波数解析し、スペクトルの安定性を検出するエッジ検出段階と、
該スペクトルの安定性から音楽を検出する音楽検出段階と、
該スペクトルのハーモニック構造を検出し、音声を検出する音声検出段階と、
音響の特徴ベクトルを学習データとしてベクトル量子化し、符号帳を生成する符号帳生成段階と、
該生成された符号帳と該映像情報に含まれる音情報の特徴ベクトルとを比較し、距離の近い音響を検出する音響検出段階と、
該検出された音情報の種類別の区間の位置を記録する属性情報蓄積段階と、
該検出された音情報の種類、各々の区間の長さ、種類毎の全体の長さ、各々の区間の位置のパターンの一以上を抽出し、該映像情報の種類を判別する映像判別段階と、
を有することを特徴とする映像分類方法。
【請求項２】　前記エッジ検出段階では、前記スペクトルを時間方向に並べたスペクトログラムから、周波数方向の微分オペレータによってエッジを検出する、
ことを特徴とする請求項１に記載の映像分類方法。
【請求項３】　前記音楽検出段階では、前記スペクトログラムの一定周波数における時間方向のエッジの強さから音楽を検出する、
ことを特徴とする請求項２に記載の映像分類方法。
【請求項４】　前記音声検出段階では、前記スペクトログラムのエッジの強い部分を除去した後に、くし形フィルタを用いてハーモニック構造を検出し、音声を検出する、
ことを特徴とする請求項２または３に記載の映像分類方法。
【請求項５】　前記音響検出段階では、参照音として一種類の音響のみを含む音情報の特徴ベクトルと、前記符号帳の重心との距離を算出し、距離が最も近くなる頻度の高い該符号帳の重心と、前記映像情報に含まれる音情報の特徴ベクトルとの距離を検出の判定基準として用いる、
ことを特徴とする請求項１、２、３、４のいずれかに記載の映像分類方法。
【請求項６】　前記映像判別段階は、検出された音情報の種類、各々の区間の長さ、種類毎の全体の長さ、各々の区間の位置を分類ベクトルとして符号帳を作成し、該符号帳の重心と、前記映像情報に含まれる音情報の分類ベクトルとの距離を判別基準に用いる、
ことを特徴とする請求項１、２、３、４、５のいずれかに記載の映像分類方法。
【請求項７】　映像情報を入力し、該入力された映像情報に含まれる音情報から音楽、音声、音響のうち少なくとも１つが存在する区間を検出し、該検出された区間の発生パターンによって映像の種類を判別する映像分類装置であって、
映像情報がアナログの場合にはＡ／Ｄ変換してディジタルの映像情報を入力する映像入力部と、
該映像情報に含まれる音情報を周波数解析し、スペクトルの安定性を検出するエッジ検出部と、
該スペクトルの安定性から音楽を検出する音楽検出部と、
該スペクトルのハーモニック構造を検出し、音声を検出する音声検出部と、
音響の特徴ベクトルを学習データとしてベクトル量子化し、符号帳を生成する符号帳生成部と、
該生成された符号帳と該映像情報に含まれる音情報の特徴ベクトルとを比較し、距離の近い音響を検出する音響検出部と、
該検出された音情報別の区間の位置を記録する属性情報蓄積部と、
該検出された音情報の種類、各々の区間の長さ、種類毎の全体の長さ、各々の区間の位置のパターンを一以上抽出し、該映像情報の種類を判別する映像判別部と、
を備えることを特徴とする映像分類装置。
【請求項８】　前記エッジ検出部は、前記スペクトルを時間方向に並べたスペクトログラムから、周波数方向の微分オペレータによってエッジを検出するものである、
ことを特徴とする請求項７に記載の映像分類装置。
【請求項９】　前記音楽検出部は、前記スペクトログラムの一定周波数における時間方向のエッジの強さから音楽を検出するものである、
ことを特徴とする請求項８に記載の映像分類装置。
【請求項１０】　前記音声検出部は、前記スペクトログラムのエッジの強い部分を除去した後に、くし形フィルタを用いてハーモニック構造を検出し、音声を検出するものである、
ことを特徴とする請求項８または９に記載の映像分類装置。
【請求項１１】　前記音響検出部は、参照音として一種類の音響のみを含む音情報の特徴ベクトルと、前記符号帳の重心との距離を算出し、距離が最も近くなる頻度の高い該符号帳の重心と、前記映像情報に含まれる音情報の特徴ベクトルとの距離を検出の判定基準として用いるものである、
ことを特徴とする請求項７、８、９、１０のいずれかに記載の映像分類装置。

【請求項１２】　前記映像判別部は、検出された音情報の種類、各々の区間の長さ、種類毎の全体の長さ、各々の区間の位置を分類ベクトルとして符号帳を作成し、該符号帳の重心と、前記映像情報に含まれる音情報の分類ベクトルとの距離を判別基準に用いるものである、
ことを特徴とする請求項７、８、９、１０、１１のいずれかに記載の映像分類装置。
【発明の詳細な説明】
【０００１】
【発明の属する技術分野】映像を効率良く扱うためには、映像の属性情報を自動的に付与する技術が必要である。属性情報は、映像制作の関連分野において、映像の編集、加工、分類等に利用される。本発明は、映像に含まれる特徴量を抽出し、特徴量に応じて映像を分類する技術に関する。
【０００２】
【従来の技術】映像の内容がどのようなものであるかを大別することは、ビデオ・オン・デマンドのようなシステムで用いられる大量の映像を効率良く扱う上で不可欠である。現在、映像は主にニュース、スポーツ、ドラマ、映画、音楽、ドキュメンタリー、教育、バラエティ、アニメ等に分類されているが、これらのうち幾つかを自動的に識別しようとする方法が提案されている。「S. Fischer et. al：Automatic Recognition of Film Genres, ACM Multimedia' 95, pp. 295－301」では、画像の色情報から場面の変わり目やカメラの動きを検出し、音情報の振幅の変化と併せて、ニュース、スポーツ（テニスおよび自動車レース）、アニメ、コマーシャルの分類を行っている。カメラの動きが少なければニュース、周期的な音の繰り返し（テニスのボールを打つ音）があればスポーツ、言葉が途切れた所にノイズが少なければアニメ（アフレコのため背景音が少ない）、場面の変わり目に全体が黒になればコマーシャルといったようにジャンル毎にみられる典型的な特徴を利用している。
【０００３】
【発明が解決しようとする課題】上記従来の技術では、主に画像情報に基づいて映像の分類を行っており、音情報についての詳しい解析は行われていない。また、画像情報から検出できる、ジャンル毎に固有の特徴が限られているため、分類できる範囲は狭い。さらに、上記のように従来から定められているジャンル毎の特徴を見つけ出すようなトップダウン的な方法では、分類できないジャンルが存在する。
【０００４】一方、映像に含まれる音情報は映像の内容を良く反映しており、内容の種類に固有の特徴を検出し易い。音情報を解析して映像一般に見られる特徴的な音を検出し、その発生パターンから映像を分類することで、ボトムアップ的な要素を取り入れた分類方法を実現することが可能である。
【０００５】本発明の目的は、映像情報に含まれる音情報を解析し、映像を既存のジャンルにとらわれないカテゴリーに分類する映像分類方法および装置を提供することにある。
【０００６】
【課題を解決するための手段】上記の目的を達成するため、本発明の映像分類方法は、映像情報がアナログの場合にはＡ／Ｄ変換してディジタルの映像情報を入力する映像入力段階と、該映像情報に含まれる音情報を周波数解析し、スペクトルの安定性を検出し、音楽を検出する音楽検出段階と、該スペクトルのハーモニック構造を検出し、音声を検出する音声検出段階と、音響の特徴ベクトルを学習データとしてベクトル量子化し、符号帳を生成する符号帳生成段階と、生成された符号帳と該映像情報に含まれる音情報の特徴ベクトルを比較し、距離の近い音響を検出する音響検出段階と、該検出された音情報の種類別の区間の位置を記録する属性情報蓄積段階と、該検出された音情報の種類、各々の区間の長さ、種類毎の全体の長さ、各々の区間の位置のパターンを一以上抽出し、該映像情報の種類を判別する映像判別段階と、を有することで、入力された映像情報に含まれる音情報から音楽、音声、音響のうち少なくとも１つが存在する区間を検出し、該検出された区間の発生パターンによって映像の種類を判別して広範囲なカテゴリに分類することが可能となる。
【０００７】また、本発明の映像分類装置は、映像情報がアナログの場合にはＡ／Ｄ変換してディジタルの映像情報を入力する映像入力部と、該映像情報に含まれる音情報を周波数解析し、スペクトルの安定性を検出し、音楽を検出する音楽検出部と、該スペクトルのハーモニック構造を検出し、音声を検出する音声検出部と、音響の特徴ベクトルを学習データとしてベクトル量子化し、符号帳を生成する符号帳生成部と、生成された符号帳と該映像情報に含まれる音情報の特徴ベクトルを比較し、距離の近い音響を検出する音響検出部と、該検出された音情報の種類別の区間の位置を記録する属性情報蓄積部と、該検出された音情報の種類、各々の区間の長さ、種類毎の全体の長さ、各々の区間の位置のパターンを一以上抽出し、該映像情報の種類を判別する映像判別部と、を具備することで、入力された映像情報に含まれる音情報から音楽、音声、音響のうち少なくとも１つが存在する区間を検出し、該検出された区間の発生パターンによって映像の種類を判別して広範囲なカテゴリに分類することが可能となる。
【０００８】上記の映像分類方法および装置では、スペクトログラムの一定周波数における時間方向のエッジの強さを検出することで、音楽を容易に検出することが可能となる。
【０００９】また、該スペクトログラムのエッジの強い

部分を除去した後に、くし形フィルタを用いてハーモニック構造を検出することで、音楽が重なっている場合でも音声を容易に検出することが可能となる。

【００１０】また、参照音として一種類の音響のみを含む音情報の特徴ベクトルと、該符号帳の重心との距離を算出し、距離が最も近くなる頻度の高い該符号帳の重心と、該映像情報に含まれる音情報の特徴ベクトルとの距離を検出の判定基準として用いることで、学習した音響を容易に検出することが可能となる。

【００１１】さらに、検出された音情報の種類、各々の区間の長さ、種類毎の全体の長さ、各々の区間の位置を分類ベクトルとして符号帳を作成し、該符号帳の重心と、該映像情報に含まれる音情報の分類ベクトルとの距離を判別基準に用いることで、映像を容易に分類することが可能となる。

【００１２】

【発明の実施の形態】次に、本発明の実施の形態について図面を参照して詳細に説明する。

【００１３】図１は、本発明の一実施形態例の映像分類装置の概略構成を示すブロック図である。

【００１４】本実施形態例の映像分類装置は、映像情報がアナログの場合にはＡ／Ｄ変換して入力する映像入力部１０１と、音情報を周波数解析して、サウンドスペクトログラムのエッジを検出し、必要に応じて除去するエッジ検出部１０２と、音情報から音楽を検出する音楽検出部１０３と、音声を検出する音声検出部１０４と、音響の学習データから符号帳を生成する符号帳生成部１０５と、学習した音響と同一種類の音を検出する音響検出部１０６と、検出された音の区間の位置を記録する属性情報蓄積部１０７と、検出された音情報の種類、各々の区間の長さ、種類毎の全体の長さ、各々の区間の位置によって、映像情報の種類を判別する映像判別部１０８から構成されている。

【００１５】映像入力部１０１から入力された映像の音データは、一方でエッジ検出部１０２に入力され、エッジ検出部１０２でＦＦＴ（高速フーリエ変換）処理されて、数秒程度の長さのサウンドスペクトログラムが生成される。ここで、ＦＦＴの代わりにＬＰＣ（線形予測分析）を用いることも可能である。また、映像入力部１０１から入力された映像の音データは、他方で音響検出部１０６に入力される。

【００１６】図２は、本発明の一実施形態例のエッジ検出部１０２、音楽検出部１０３、音声検出部１０４の処理を示したフローチャートである。以下、図１及び図２を参照してそれらの動作例を説明する。

【００１７】エッジ検出部１０２のＦＦＴ処理２０１によってスペクトログラムが生成される。その際のフレーム長は、数十～百ミリ秒で、検出区間は、数秒である。

【００１８】図３に、生成されたスペクトログラムの様子を簡略化して示す。スペクトログラムは、実際には、濃淡画像として得られる。３０１は、音楽成分のスペクトルの軌跡であり、３０２は、音声成分のスペクトルの軌跡である。音楽成分は、周波数方向に安定した軌跡を描くので、この性質を利用して検出する。まず、周波数ｉにおける時間方向のエッジＥＤｉをエッジ検出処理２０２で微分オペレータを用いて検出する。得られたエッジＥＤｉの値をエッジの閾値処理２０３で閾値ＴＨ１と比較し、エッジＥＤｉの値が閾値ＴＨ１よりも大きい場合には、音声検出の前処理として周波数ｉのスペクトルをエッジ消去、補間処理２０４において０にし、エッジを消去する。また、近傍のスペクトルの値を用いて消去されたスペクトルは、線形補間される。この処理を全ての帯域について繰り返す。繰り返し判定処理２０５において、ｉがｎ－１と等しくなれば繰り返しを終える。ここでｎはＦＦＴのフレーム長のポイント数である。

【００１９】次に、エッジの強さの総和をエッジ強度算出処理２０６で算出し、エッジ強度の閾値処理２０７において、算出されたエッジの強さが閾値ＴＨ２よりも大きい場合に音楽が存在すると判断する。

【００２０】図３の３０２に示すように、音声成分は時間的に変動する等間隔の縞模様として現れるので、エッジ強度算出処理２０６と平行してスペクトログラムにくし形フィルタ処理２０８を施し、フィルタ出力の閾値処理２０９において、フィルタ処理の出力が閾値ＴＨ３よりも大きければ音声が存在すると判断する。

【００２１】図４は、本発明の一実施形態例の図１の音響検出部１０６の処理を示したフローチャートである。音響の種類の例としては、笑声、歓声、拍手、雑踏、機械の音等が考えられる。ここでは、笑声、歓声、拍手を例に取って説明する。

【００２２】笑声、歓声、拍手のような音響は、明確な構造がスペクトルに現れないため、ベクトル量子化を利用して検出する。まず、各々の音響データのサンプルを用意し、符号帳生成部１０５で符号帳を作成する。使用するベクトルの特徴量としては、数十～百ミリ秒のフレーム長で、１６次元程度の線形予測係数を用いる。ＬＰＣケプストラム、ＦＦＴケプストラム、フィルタバンク出力等を用いることも可能である。サンプルデータは、多いほど良好な結果を得ることができる。笑声、歓声、拍手の３つのカテゴリーに分類するため、各サンプルデータの係数から３つ以上ののクラスタを生成する。以下では、クラスタの数が３つの場合を例に取り説明する。まず、クラスタの重心ベクトルをＣ１，Ｃ２，Ｃ３とする。Ｃ１，Ｃ２，Ｃ３が、笑声、歓声、拍手のどの重心ベクトルに対応するかは、カテゴリーが既知のサンプルデータが最も近い重心ベクトルを調べることで、容易に分かる。

【００２３】入力された映像の音データの線形予測係数は線形予測係数算出処理４０１で算出され、各々の重心ベクトルとの距離Ｌｉがベクトル距離算出処理４０２で

算出される。次に、最小距離ベクトルの閾値処理４０３において重心ベクトルとの距離Ｌｉの大きさを調べ、閾値ＴＨ４よりも大きい場合には、３つのカテゴリーには属さないと判断し、非音響と判断される。閾値ＴＨ４よりも小さい場合には、最小距離ベクトル判別処理４０４、最小距離ベクトル判別処理４０５により重心ベクトルとの距離Ｌｉの中で最も距離の短いものを選択し、対応するカテゴリーに属すると判断する。図４では、Ｃ１，Ｃ２，Ｃ３が各々、笑声、歓声、拍手に対応している場合を示している。

【００２４】特徴音検出部１０２で検出された音の始点と終点の位置は、属性情報の一部として属性情報蓄積部１０７にタイムコードや、先頭からのバイト数等のフォーマットで記録される。

【００２５】映像判別部１０６では、属性情報蓄積部１０７から情報を読み出し、映像シーケンス全体における各々の音の含有率を算出し、分類ベクトルＶ（ｖ１，ｖ２，ｖ３，ｖ４，ｖ５，ｖ６）を求める。ここで、ｖ１，ｖ２，ｖ３，ｖ４，ｖ５，ｖ６は、各々、音楽、音声、笑声、歓声、拍手、音楽と音声が重なっている区間、の含有率である。

【００２６】分類ベクトルを用いて映像を分類する際には、音響検出と同様にベクトル量子化が用いられる。様々な映像サンプルを用いて分類ベクトルを求め、必要なジャンルの数だけクラスタリングを行い、重心ベクトルを求める。入力された映像の分類ベクトルと重心ベクトルの距離を算出し、最も近いクラスタに割り当てる。形成されるクラスタは、一般的に用いられるジャンルと必ずしも一致しないが、音声が多く、音楽が少なければニュースや教育、逆の場合は音楽、笑声が多い場合はコメディ等といった分類が可能である。

【００２７】図５は、本実施形態例の映像分類装置をソフトウェアで実現した場合の処理を示すフローチャートである。映像は、まず、符号帳生成段階５００で、音響の学習データから符号帳が生成され、映像入力段階５０１から入力され、エッジ検出段階５０２で周波数解析、エッジ検出が行われる。また、必要に応じてエッジの削除、補間が行われる。音楽検出段階５０３および音声検出段階５０４では、各々、エッジの強さ、くし形フィルタを用いて音楽および音声が検出される。音響検出段階５０５では、ベクトル量子化を用いて、笑声、歓声、拍手が検出される。検出された音の始点と終点の情報は、属性情報検出段階５０６で蓄積され、映像シーケンスの最後に到達した時点で映像判別段階５０７において映像が分類される。

【００２８】

【発明の効果】以上説明したように、本発明は以下のような効果を奏する。

【００２９】（１）映像情報に含まれる音情報から音楽、音声、笑声、歓声、拍手を検出し、検出された音情報の種類、各々の区間の長さ、種類毎の全体の長さ、各々の区間の位置のパターンを比較するようにしたので、映像を広範囲なカテゴリに分類することができる。

【００３０】（２）スペクトログラムの一定周波数における時間方向のエッジの強さを検出するようにした場合には、特に音楽を容易に検出することができる。

【００３１】（３）スペクトログラムのエッジの強い部分を除去した後に、くし形フィルタを用いてハーモニック構造を検出するようにした場合には、特に言葉などの音声を容易に検出することができる。

【００３２】（４）参照音として一種類の音響のみを含む音情報の特徴ベクトルと、該符号帳の重心との距離を算出し、距離が最も近くなる頻度の高い該符号帳の重心と、該映像情報に含まれる音情報の特徴ベクトルとの距離を検出の判定基準として用いるようにした場合には、特に学習した音響を容易に検出することができる。

【００３３】（５）検出された音情報の種類、各々の区間の長さ、種類毎の全体の長さ、各々の区間の位置を分類ベクトルとして符号帳を作成し、判別の判定基準に、該符号帳の重心と、該映像情報に含まれる音情報の分類ベクトルとの距離を用いるようにした場合には、特に映像を容易に広範囲なカテゴリに分類することができる。

【図面の簡単な説明】

【図１】本発明の一実施形態例の映像分類装置の概略構成を示すブロック図である。

【図２】上記実施形態例の特徴音検出部分における音楽と音声の検出処理を示すフローチャートである。

【図３】上記実施形態例のエッジ検出部において得られたサウンドスペクトログラムの様子を示す概念図である。

【図４】上記実施形態例の特徴音検出部分における笑声、歓声および拍手の検出処理を示すフローチャートである。

【図５】上記実施形態例の映像分類装置を計算機を用いてソフトウェア的に実現した場合の処理の流れを示すフローチャートである。

【符号の説明】

１０１…映像入力部
１０２…エッジ検出部
１０３…音楽検出部
１０４…音声検出部
１０５…符号帳生成部
１０６…音響検出部
１０７…映像判別部
１０８…属性情報蓄積部
２０１…ＦＦＴ（高速フーリエ変換）処理
２０２…エッジ検出処理
２０３…エッジの閾値処理
２０４…エッジ消去、補間処理
２０５…繰り返し判定処理

２０６…エッジ強度算出処理
２０７…エッジ強度の閾値処理
２０８…くし形フィルタ処理
２０９…フィルタ出力の閾値処理
３０１…音楽スペクトルピーク
３０２…音声スペクトルピーク
４０１…線形予測係数算出処理
４０２…ベクトル距離算出処理
４０３…最小距離ベクトルの閾値処理
４０４…最小距離ベクトル判別処理
４０５…最小距離ベクトル判別処理
５００…符号帳生成段階
５０１…映像入力段階
５０２…エッジ検出段階
５０３…音楽検出段階
５０４…音声検出段階
５０５…音響検出段階
５０６…属性情報蓄積段階
５０７…映像判別段階

【図１】

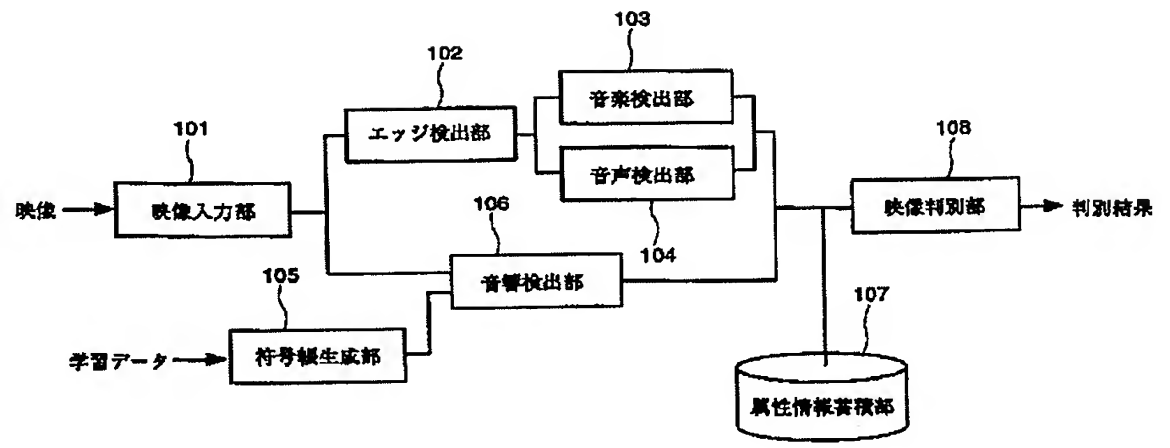

【図３】

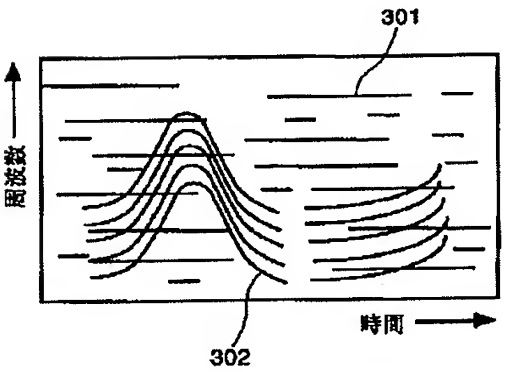

【図５】

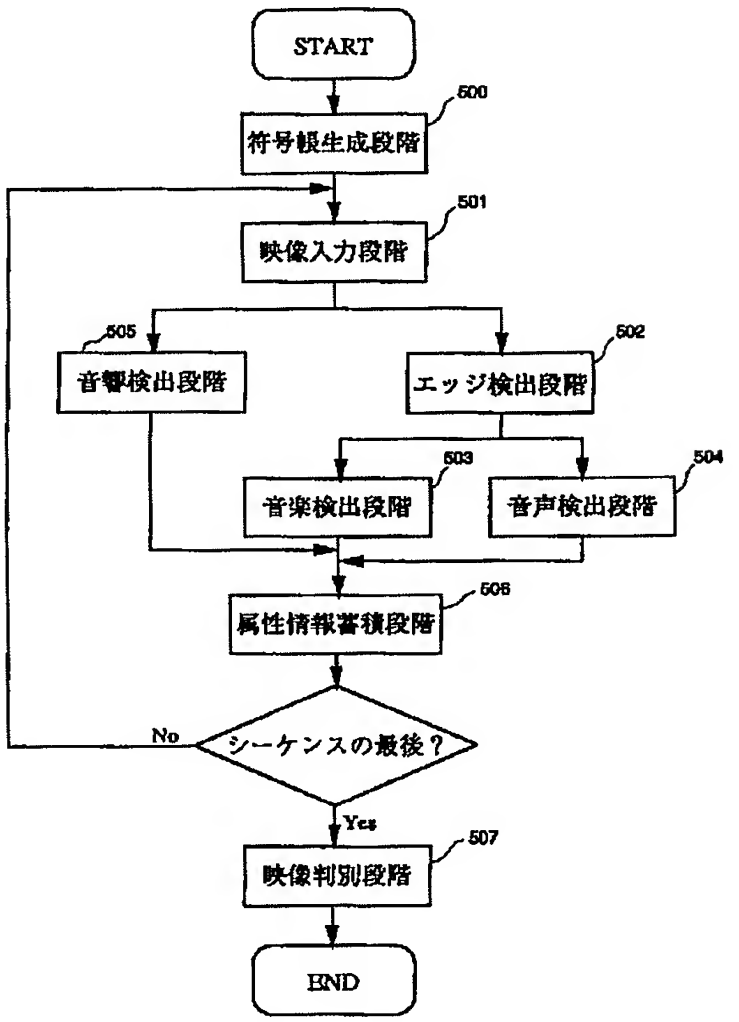

【図２】

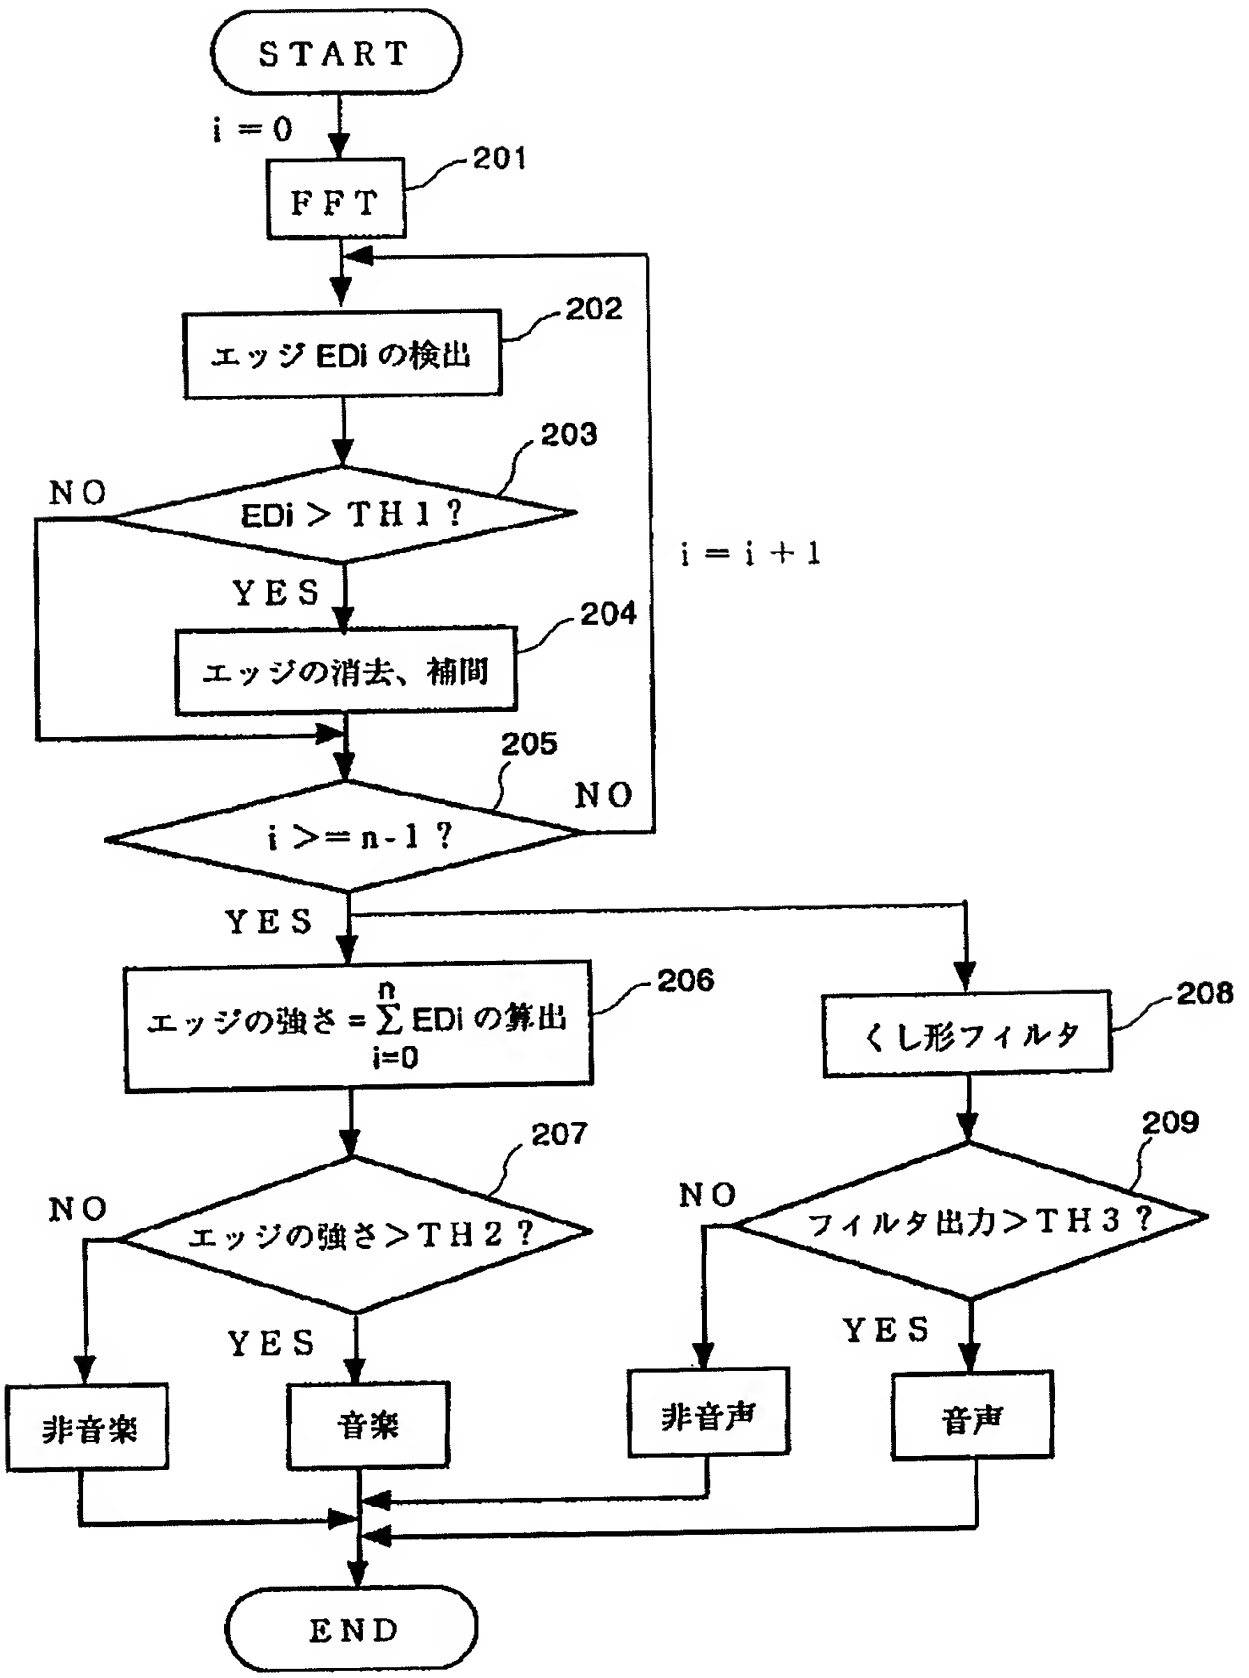
START
i＝0
201
FFT
202
エッジEDiの検出
203
NO
EDi＞TH1？
YES
i＝i＋1
204
エッジの消去、補間
205
NO
i＞＝n-1？
YES
206
エッジの強さ＝Σ EDiの算出
i=0
208
くし形フィルタ
207
NO
エッジの強さ＞TH2？
YES
209
NO
フィルタ出力＞TH3？
YES
非音楽
音楽
非音声
音声
END

【図４】

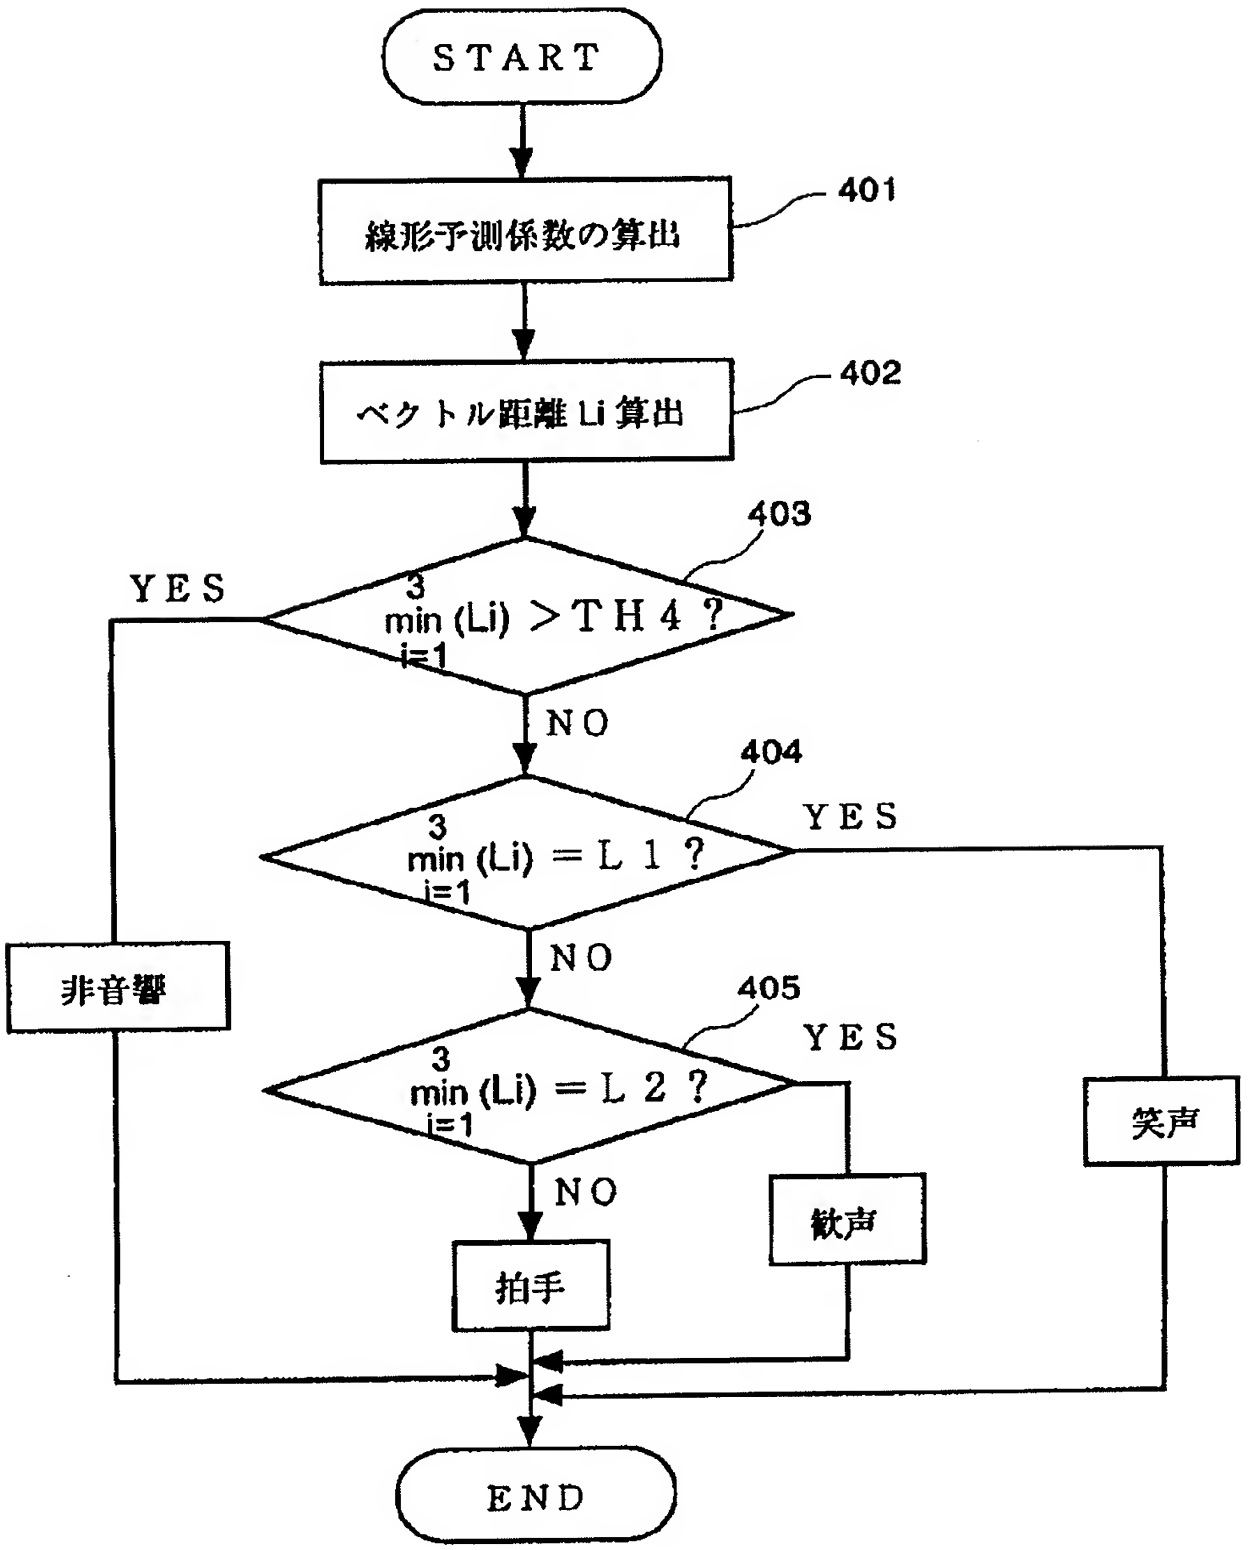
START
線形予測係数の算出
401
ベクトル距離 Li 算出
402
403
YES
3
min (Li) ＞ＴＨ４ ?
i=1
NO
404
3
min (Li) ＝Ｌ１ ?
i=1
YES
非音響
NO
405
3
min (Li) ＝Ｌ２ ?
i=1
YES
笑声
NO
歓声
拍手
END

PATENT ABSTRACTS OF JAPAN

(11)Publication number : 10-187182
(43)Date of publication of application : 14.07.1998

(51)Int.Cl. G10L 3/00
G10L 3/00
G10L 3/00
H04N 5/91

(21)Application number : 08-340293
(22)Date of filing : 20.12.1996

(71)Applicant : NIPPON TELEGR & TELEPH CORP <NTT>
(72)Inventor : MINAMI KENICHI
AKUTSU AKITO
TONOMURA YOSHINOBU

(54) METHOD AND DEVICE FOR VIDEO CLASSIFICATION

(57)Abstract:
PROBLEM TO BE SOLVED: To provide the method and the device in which an analysis is conducted for the sound information included in video information and the video is classified into categories without being influenced by conventional categories.
SOLUTION: A music detecting section 103 conducts a frequency analysis of the sound information of the inputted video informationdetects the stability of the spectra and detects a music. A voice detecting section 104 detects the harmonic structure of the spectrum and detects voices. On the other handa code table generating section 105 generates a code table. Thenan acoustic detecting section 106 compares the sound information of the inputted video information with the feature vectors of the code table and the kinds of acoustics are detected by the closeness of the distance between the sound information and the feature vectors. An attribute information accumulating section 107 records the position of the segment of the detected sound information and extracts the kinds of the detected sound informationthe length of each segmentthe total length of every kind and the pattern of the position of each segment and a video discriminating section 108 discriminates the kind of the video information.

CLAIMS

[Claim(s)]
[Claim 1]An image classifying method which detects musica soundand the section

when at least one of sound exists from sound information characterized by comprising the following which inputs video information and is included in this inputted video informationand distinguishes a kind of image with occurrence patterns of the this detected section.
A video input stage of carrying out an A/D conversion and inputting digital video information when video information is an analog.
An edge detection stage of conducting frequency analysis of the sound information included in this video informationand detecting the stability of a spectrum.
A music detection stage which detects music from the stability of this spectrum.
A voice detection stage of detecting harmonic structure of this spectrum and detecting a soundA code book generation phase which vector-quantizes an acoustic feature vector as learned dataand generates a code bookA sound detection stage which compares a generated this code book with a feature vector of sound information included in this video informationand detects sound with a near distanceA stage according to image format which extracts one or more [of a pattern of an attribution information accumulation stage which records a position of the section according to kind of detected this sound informationand a kind of this detected sound informationthe length of each sectionlength for every whole kind and a position of each section]and distinguishes a kind of this video information.

[Claim 2]The image classifying method according to claim 1 characterized by what a differentiation operator of a frequency direction detects edge for in said edge detection stage from a spectrogram which arranged said spectrum in a time direction.
[Claim 3]The image classifying method according to claim 2 characterized by what music is detected for from strength of edge of a time direction in constant frequency of said spectrogram in said music detection stage.
[Claim 4]The image classifying method according to claim 2 or 3 characterized by what a radial fin type filter is usedharmonic structure is detectedand a sound is detected for after removing a portion with strong edge of said spectrogram in said voice detection stage.
[Claim 5]A feature vector of sound information which contains only one kind of sound as a reference sound in said sound detection stageAn image classifying method given in either of claims 123and 4 characterized by what distance with the center of gravity of said code book is computedand is used as a judging standard of detection of distance of the center of gravity of this code book with high frequency where distance becomes the nearestand a feature vector of sound information included in said video information.
[Claim 6]A stage according to said image format creates a code book by making a kind of detected sound informationthe length of each sectionlength for every whole kindand a position of each section into a classification vectorand The center of gravity of this code bookAn image classifying method given in either of claims

1234and 5 characterized by what distance with a classification vector of sound information included in said video information is used for a distinction standard for.
[Claim 7]An image classifying apparatus which detects musica soundand the section when at least one of sound exists from sound information characterized by comprising the following which inputs video information and is included in this inputted video informationand distinguishes a kind of image with occurrence patterns of the this detected section.
A video input section which carries out an A/D conversion and inputs digital video information when video information is an analog.
An edge detection section which conducts frequency analysis of the sound information included in this video informationand detects the stability of a spectrum.
A music primary detecting element which detects music from the stability of this spectrum.
A voice detection part which detects harmonic structure of this spectrum and detects a soundA code book generation part which vector-quantizes an acoustic feature vector as learned dataand generates a code bookA sound primary detecting element which compares a generated this code book with a feature vector of sound information included in this video informationand detects sound with a near distanceA part according to image format which extracts an attribution information accumulating part which records a position of the section according to detected this sound informationa kind of this detected sound informationthe length of each sectionlength for every whole kindand a pattern of a position of each section one or moreand distinguishes a kind of this video information.

[Claim 8]The image classifying apparatus according to claim 7 characterized by what said edge detection section is what detects edge from a spectrogram which arranged said spectrum in a time direction with a differentiation operator of a frequency direction.
[Claim 9]The image classifying apparatus according to claim 8 characterized by what said music primary detecting element is what detects music from strength of edge of a time direction in constant frequency of said spectrogram.
[Claim 10]The image classifying apparatus according to claim 8 or 9 characterized by what is been what uses a radial fin type filterdetects harmonic structureand detects a sound after said voice detection part removes a portion with strong edge of said spectrogram.
[Claim 11]A feature vector of sound information in which said sound primary detecting element contains only one kind of sound as a reference soundAn image classifying apparatus given in either of claims 789and 10 characterized by what is been what is used as a judging standard of detection of distance of the center of gravity of this code book with high frequency where distance with the center of gravity of said code book is computedand distance becomes the nearestand a feature vector of sound information included in said video information.
[Claim 12]A part according to said image format makes a classification vector a

kind of detected sound informationthe length of each sectionlength for every whole kindand a position of each sectioncreate a code bookand The center of gravity of this code bookAn image classifying apparatus given in either of claims 78910and 11 characterized by what is been what uses for a distinction standard distance with a classification vector of sound information included in said video information.

DETAILED DESCRIPTION

[Detailed Description of the Invention]
[0001]
[Field of the Invention]In order to treat an image efficientlythe art which gives the attribution information of an image automatically is required. Attribution information is used for edit of an imageprocessinga classificationetc. in the related field of image work. This invention extracts the characteristic quantity contained in an imageand relates to the art of classifying an image according to characteristic quantity.
[0002]
[Description of the Prior Art]It is indispensable to divide roughly what kind of things the contents of the image arewhen treating efficiently a lot of images used by a system like video on demand. Although the image is mainly classified into newsa sporta dramaa moviemusicdocumentaryeducationvarietyanimeetc. nowthe method of identifying some automatically among these is proposed. In "S. Fischer et.al:Automatic Recognition of Film GenresACM Multimedia'95and pp.295-301." The change of a scene and a motion of a camera are detected from the sexual desire news of a pictureit combines with change of the amplitude of sound informationand the classification of newsa sport (tennis and car race)animeand commercials is performed. If there are few motions of a camera and there is a repetition (sound which hits the ball of tennis) of news and a periodic sounda sportIf the place where language broke off has few noises and the whole will become black at the change of anime (there are few background sounds because of postrecording)and a scenethe typical feature regarded as having called it commercials for every genre will be used.
[0003]
[Problem(s) to be Solved by the Invention]According to the above-mentioned conventional artthe image is mainly classified based on picture informationand detailed analysis about sound information is not conducted with it. Since the peculiar feature is restricted for every genre detectable from picture informationthe range which can be classified is narrow. The genre which cannot be classified exists in the top-down method that the feature for every genre defined from the former as mentioned above is found out.
[0004]On the other handthe sound information included in an image is reflecting the contents of the image welland tends to detect the feature peculiar to the kind

of contents. It is possible to realize the classifying method which took in the bottom-up element by detecting the characteristic sound which analyzes sound information and is looked at by the general imageand classifying an image from the occurrence patterns.
[0005]The purpose of this invention analyzes the sound information included in video informationand there is in providing the image classifying method and device which classify an image into the category which is not caught by the existing genre.
[0006]
[Means for Solving the Problem]In order to attain the above-mentioned purposean image classifying method of this inventionA video input stage of carrying out an A/D conversion and inputting digital video information when video information is an analogA music detection stage which conducts frequency analysis of the sound information included in this video informationdetects the stability of a spectrumand detects musicA voice detection stage of detecting harmonic structure of this spectrum and detecting a soundA code book generation phase which vector-quantizes an acoustic feature vector as learned dataand generates a code bookA sound detection stage which compares a feature vector of a generated code book and sound information included in this video informationand detects sound with a near distanceAn attribution information accumulation stage which records a position of the section according to kind of detected this sound informationBy having a stage according to image format which extracts a kind of detected this sound informationthe length of each sectionlength for every whole kindand a pattern of a position of each section one or moreand distinguishes a kind of this video information. It becomes possible to detect musica soundand the section when at least one of sound exists from sound information included in inputted video informationto distinguish a kind of image and to classify into a wide range category according to occurrence patterns of the this detected section.
[0007]A video input section which carries out the A/D conversion of the image classifying apparatus of this invention when video information is an analogand inputs digital video informationA music primary detecting element which conducts frequency analysis of the sound information included in this video informationdetects the stability of a spectrumand detects musicA voice detection part which detects harmonic structure of this spectrum and detects a soundA code book generation part which vector-quantizes an acoustic feature vector as learned dataand generates a code bookA sound primary detecting element which compares a feature vector of a generated code book and sound information included in this video informationand detects sound with a near distanceAn attribution information accumulating part which records a position of the section according to kind of detected this sound informationBy providing a part according to image format which extracts a kind of detected this sound informationthe length of each sectionlength for every whole kindand a pattern of a position of each section one or moreand distinguishes a kind of this video information. It becomes possible to detect musica soundand the section when at least one of sound exists from sound information included in inputted video informationto distinguish a kind

of image and to classify into a wide range category according to occurrence patterns of the this detected section.
[0008]In above image classifying method and devicedetecting strength of edge of a time direction in constant frequency of a spectrogram enables it to detect music easily.
[0009]After removing a portion with strong edge of this spectrogrameven when music has lappedit becomes possible by using a radial fin type filter and detecting harmonic structure to detect a sound easily.
[0010]A feature vector of sound information which contains only one kind of sound as a reference soundDistance with the center of gravity of this code book is computedand distance becomes possible [detecting learned sound easily by using as a judging standard of detection of distance of the center of gravity of this code book with high frequency which becomes the nearestand a feature vector of sound information included in this video information].
[0011]Create a code book by making a kind of detected sound informationthe length of each sectionlength for every whole kindand a position of each section into a classification vectorand The center of gravity of this code bookIt becomes possible to classify an image according to using for a distinction standard distance with a classification vector of sound information included in this video information easily.
[0012]
[Embodiment of the Invention]Nextan embodiment of the invention is described in detail with reference to drawings.
[0013]Drawing 1 is a block diagram showing the outline composition of the image classifying apparatus of the example of 1 embodiment of this invention.
[0014]The video input section 101 which carries out the A/D conversion of the image classifying apparatus of this example of an embodiment when video information is an analogand is inputtedThe edge detection section 102 which conducts frequency analysis of the sound informationdetects the edge of a sound spectrogramand is removed if neededThe music primary detecting element 103 which detects music from sound informationand the voice detection part 104 which detects a soundThe code book generation part 105 which generates a code book from acoustic learned dataand the learned sound and the sound primary detecting element 106 which detects the sound of an identical kindThe parts 108 according to image format which distinguish the kind of video information are consisted of by the attribution information accumulating part 107 which records the position of the section of the detected soundthe kind of detected sound informationthe length of each sectionthe length for every whole kindand the position of each section.
[0015]The sound data of an image inputted from the video input section 101 is inputted into the edge detection section 102 by one sideFFT (Fast Fourier Transform) processing is carried out by the edge detection section 102and the sound spectrogram of the length for about several seconds is generated. Hereit is also possible to use LPC (linear predictive coding) instead of FFT. The sound data

of an image inputted from the video input section 101 is inputted into the sound primary detecting element 106 on the other hand.
[0016]Drawing 2 is the flow chart which showed processing of the edge detection section 102 of the example of 1 embodiment of this inventionthe music primary detecting element 103and the voice detection part 104. Hereafterthose examples of operation are explained with reference to drawing 1 and drawing 2.
[0017]A spectrogram is generated by the FFT processing 201 of the edge detection section 102. The frame length in that case is tens-100 millisecondsand a detection interval is several seconds.
[0018]The situation of the generated spectrogram is simplified and shown in drawing 3. A spectrogram is actually obtained as a shade image. 301 is a locus of the spectrum of a music ingredient and 302 is a locus of the spectrum of a voice component. Since the locus stable in the frequency direction is drawna music ingredient is detected using this character. Firstthe edge EDi of the time direction in the frequency i is detected using a differentiation operator by the edge detection process 202. When the value of the edge EDi is larger than threshold TH1 in the value of the obtained edge EDi at the threshold process 203 of edge as compared with threshold TH1the spectrum of the frequency i is set to 0 in edge elimination and the interpolation processing 204 as pretreatment of voice detectionand edge is eliminated. Linear interpolation of the spectrum eliminated using the value of a nearby spectrum is carried out. This processing is repeated about all the zones. In the repetition decision processing 205if i becomes equal to n-1a repetition will be finished. n is a point size of the frame length of FFT here.
[0019]Nexttotal of the strength of edge is computed by the edge intensity calculation processing 206and in the threshold process 207 of edge intensitywhen the strength of the computed edge is larger than threshold TH2it is judged that music exists.
[0020]Since a voice component appears as a striped pattern at equal intervals changed in time as shown in 302 of drawing 3In parallel with the edge intensity calculation processing 206radial-fin-type-filter processing 208 is performed to a spectrogramand in the threshold process 209 of a filter outputif the output of filtering is larger than threshold TH3it will be judged that a sound exists.
[0021]Drawing 4 is the flow chart which showed processing of the sound primary detecting element 106 of drawing 1 of the example of 1 embodiment of this invention. As an example of an acoustic kindthe sound of ****a cheerapplausebustleand machineryetc. can be considered. Hereit explains taking the case of ****a cheerand applause.
[0022]Since a clear structure does not appear in a spectrum****a cheerand sound like applause are detected using vector quantization. Firstthe sample of each sound data is prepared and a code book is created by the code book generation part 105. As characteristic quantity of the vector to be usedit is the frame length of tens-100 millisecondsand the linear predictor coefficients of about 16-dimensional one are used. It is also possible to use LPC cepstrumFFT cepstruma filter bank outputetc. Sample data can obtain such a good result that it

is large. In order to classify into ****a cheerand three categories of applausethe cluster of or more three ** is generated from the coefficient of each sample data. Belowit explains taking the case of the case where the number of clusters is three. Firstthe center-of-gravity vector of a cluster is set to C1C2and C3. With ****a cheerand which center-of-gravity vector of applause C1C2and C3 deal is that the sample data whose category is known investigates the nearest center-of-gravity vectorand it is known easily.

[0023]The linear predictor coefficients of the inputted sound data of an image are computed by the linear-predictor-coefficients calculation processing 401and the distance Li with each center-of-gravity vector is computed by the vector distance calculation processing 402. Nextin the threshold process 403 of a shortest distance vectorthe size of the distance Li with a center-of-gravity vector is investigatedand when larger than threshold TH4it judges that it does not belong to three categoriesand is judged as non-sound. In being smaller than threshold TH4it judges that what has the shortest distance is chosen in the distance Li with a center-of-gravity vector by the shortest distance vector discrimination processing 404 and the shortest distance vector discrimination processing 405and it belongs to a corresponding category. Drawing 4 shows the case where C1C2and C3 support ****a cheerand applause respectively.

[0024]The position of the starting point of a sound and a terminal point detected in the feature sound primary detecting element 102 is recorded on the attribution information accumulating part 107 in the format of a time codethe number of bytes from a headetc. as a part of attribution information.

[0025]In the part 106 according to image formatinformation is read from the attribution information accumulating part 107the content of each sound in the whole picture sequence is computedand the classification vector V (v1v2v3v4v5v6) is searched for. Herev1v2v3v4v5and v6 are the content of section ** to which the sound has lapped with musica sound****a cheerapplauseand music respectively.

[0026]When classifying an image using a classification vectorvector quantization as well as sound detection is used. A classification vector is searched for using various image samplesonly the number of required genres clusters and a center-of-gravity vector is searched for. The inputted distance of the classification vector of an image and a center-of-gravity vector is computedand it assigns the nearest cluster. Although the cluster formed is not necessarily in agreement with the genre generally usedif there is little musicwhen reverse and there are [newseducationand] much music and ****the classification of a comedy etc. is possible [there are many soundsand].

[0027]Drawing 5 is a flow chart which shows processing when software realizes the image classifying apparatus of this example of an embodiment. An image is the code book generation phase 500 firsta code book is generated from acoustic learned datait is inputted from the video input stage 501and frequency analysis and edge detection are performed in the edge detection stage 502. Deletion of edge and interpolation are performed if needed. In the music detection stage 503

and the voice detection stage 504music and a sound are respectively detected using the strength of edgeand a radial fin type filter. In the sound detection stage 505****a cheerand applause are detected using vector quantization. The detected information on the starting point of a sound and a terminal point is accumulated by the attribution information detection stage 506and when the last of a picture sequence is reachedan image is classified in the stage 507 according to image format.

[0028]

[Effect of the Invention]As explained abovethis invention does the following effects so.

[0029](1) Since musica sound****a cheerand applause are detected from the sound information included in video information and it was made to compare the kind of detected sound informationthe length of each sectionthe length for every whole kindand the pattern of the position of each sectionan image can be classified into a wide range category.

[0030](2) Especially when the strength of the edge of the time direction in the constant frequency of a spectrogram is detectedmusic can be detected easily.

[0031](3) Especially when a radial fin type filter is used and harmonic structure is detected after removing a portion with strong edge of a spectrogramsoundssuch as languagecan be detected easily.

[0032](4) The feature vector of the sound information which contains only one kind of sound as a reference soundDistance with the center of gravity of this code book is computedand especially when it is made to use as a judging standard of detection of the distance of the center of gravity of this code book with high frequency where distance becomes the nearestand the feature vector of the sound information included in this video informationthe learned sound can be detected easily.

[0033]Create a code book by making the kind of detected sound informationthe length of each sectionthe length for every whole kindand the position of each section into a classification vectorand to the judging standard of distinction (5) The center of gravity of this code bookEspecially when distance with the classification vector of the sound information included in this video information is usedan image can be easily classified into a wide range category.

DESCRIPTION OF DRAWINGS

[Brief Description of the Drawings]

[Drawing 1]It is a block diagram showing the outline composition of the image classifying apparatus of the example of 1 embodiment of this invention.

[Drawing 2]It is a flow chart which shows the detection processing of the music in the feature sound detection section of the above-mentioned example of an embodimentand a sound.

[Drawing 3]It is a key map showing the situation of the sound spectrogram

obtained in the edge detection section of the above-mentioned example of an embodiment.

[Drawing 4]It is a flow chart which shows **** in the feature sound detection section of the above-mentioned example of an embodimenta cheerand the detection processing of applause.

[Drawing 5]It is a flow chart which shows the flow of processing at the time of realizing the image classifying apparatus of the above-mentioned example of an embodiment by software using a computer.

[Description of Notations]

101 -- Video input section
102 -- Edge detection section
103 -- Music primary detecting element
104 -- Voice detection part
105 -- Code book generation part
106 -- Sound primary detecting element
107 -- Part according to image format
108 -- Attribution information accumulating part
201 -- FFT (Fast Fourier Transform) processing
202 -- Edge detection process
203 -- Threshold process of edge
204 -- Edge eliminationinterpolation processing
205 -- Repetition decision processing
206 -- Edge intensity calculation processing
207 -- Threshold process of edge intensity
208 -- Radial-fin-type-filter processing
209 -- Threshold process of a filter output
301 -- Music spectral peak
302 -- Voice spectral peak
401 -- Linear-predictor-coefficients calculation processing
402 -- Vector distance calculation processing
403 -- Threshold process of a shortest distance vector
404 -- Shortest distance vector discrimination processing
405 -- Shortest distance vector discrimination processing
500 -- Code book generation phase
501 -- Video input stage
502 -- Edge detection stage
503 -- Music detection stage
504 -- Voice detection stage
505 -- Sound detection stage
506 -- Attribution information accumulation stage
507 -- Stage according to image format